22 | NLP基础（下）：详解语言模型与注意力机制

2021-12-01 方远

《PyTorch深度学习实战》 课程介绍 >

讲述：方远

时长 12:59 大小 11.90M

你好，我是方远。

在上节课中，我们一同了解了 NLP 任务中的几个经典问题，这些方法各有千秋，但是我们也发现，有的方法并不能很好地将文本中单词、词组的顺序关系或者语义关系记录下来，也就是说，不能很好地量化表示，也不能对语言内容不同部分的重要程度加以区分。

那么，有没有一种方法，可以把语言变成一种数学计算过程，比如采用概率、向量等方式对语言的生成和分析加以表示呢？答案当然是肯定的，这就是这节课我们要讲到的语言模型。

那如何区分语言不同部分的重要程度呢？我会从深度学习中最火热的注意力机制这一角度为你讲解。

语言模型

语言模型是根据语言客观事实而进行的语言抽象数学建模，是一种对应关系。很多 NLP 任务中，都涉及到一个问题：对于一个确定的概念或者表达，判断哪种表示结果是最有可能的。

我们结合两个例子体会一下。

先看第一个例子，翻译文字是：今天天气很好。可能的结果是： res1 = Today is a fine day. res2 = Today is a good day. 那么我们最后要的结果就是看概率 P(res1) 和 P(res2) 哪个更大。

再比如说，问答系统提问：我什么时候才能成为亿万富翁。可能的结果有：ans1 = 白日做梦去吧。ans2 = 红烧肉得加点冰糖。那么，最后返回的答案就要选择最贴近问题内容本身的结果，这里就是前一个答案。

对于上面例子中提到的问题，我们很自然就会联想到，可以使用概率统计的方法来建立一个语言模型，这种模型我们称之为统计语言模型。

统计语言模型

统计语言模型的原理，简单来说就是计算一句话是自然语言（也就是一个正常句子）的概率。多年以来，专家学者构建出了非常多的语言模型，其中最为经典的就是基于马尔可夫假设 n-gram 语言模型，它也是被广泛采用的模型之一。

接下来我们先从一个简单的抽象例子出发，来了解一下什么是统计语言模型。

给定一个句子 S=w1,w2,w3,...,wn，则生成该句子的概率为：p(S)=p(w1,w2,w3,w4,w5,...,wn)，再由链式法则我们可以继续得到：p(S)=p(w1)p(w2|w1)p(w3|w1,w2)...p(wn|w1,w2,...,wn-1)。那么这个 p(S) 就是我们所要的统计语言模型。

那么问题来了，你会发现从 p(w1,w2,w3,w4,w5,...,wn) 到 p(w1)p(w2|w1)p(w3|w1,w2)...p(wn|w1,w2,...,wn-1) 无非是一个概率传递的过程，有一个非常本质的问题并没有被解决，那就是语料中数据必定存在稀疏的问题，公式中的很多部分是没有统计值的，那就成了 0 了，而且参数量真的实在是太大了。

怎么办呢？我们观察一下后面这句话：“我们本节课将会介绍统计语言模型及其定义”。其中“定义”这个词，是谁的定义呢？是“其”的。那“其”又是谁呢？是前面的“语言模型”的。于是我们发现，**对于文本中的一个词，它出现的概率，很大程度上是由这个单词前面的一个或者几个单词决定的，**这就是马尔可夫假设。

有了马尔可夫假设，我们就可以把前面的公式中的 p(wn|w1,w2,...,wn-1) 进一步简化，简化的程度取决于你认为一个单词是由前面的几个单词所决定的，如果只由前面的一个单词决定，那它就是 p(wn|wn-1)，我们称之为 bigram。如果由前面两个单词决定，则变为 p(wn|wn-2wn-1)，我们称之为 trigram。

当然了，如果你认为单词的出现仅由其本身决定的，与其他单词无关，就变成了最简单的形式：p(wn)，我们称之为 unigram（一元模型）。

那么现在我们知道了，基于马尔可夫链的统计语言模型，其核心就在于基于统计的条件概率。为了计算一个句子的生成概率，我们只需要统计每个词及其前面 n 个词的共现条件概率，再经过简单的乘法计算就可以得到最终结果了。

神经网络语言模型

ngram 模型一定程度上减少了参数的数量，但是如果 n 比较大，或者相关语料比较少的时候，数据稀疏问题仍然不能得到很好地解决。

这就好比我们把水浒传的文本放入模型中进行统计训练，最后却问模型林冲和潘金莲的关系，这就很难回答了。

因为基于 ngram 的统计模型实在是收集不到两者共现的文本。这种稀疏问题靠统计肯定不行了。那么怎么办呢？这时候就轮到神经网络语言模型闪亮登场了。

其实从本质上说，神经网络语言模型也是通过 ngram 来进行语言的建模，但是神经网络的学习不是通过计数统计的方法，而是通过神经网络内部神经元针对数据不断更新。

具体是怎么做的呢？首先我们要定义一个向量空间，假定这个空间是一百维的，这就意味着，对于每个单词，我们可以用一个一百维的向量对其进行表示，比如 V(中国)= [0.2821289, 0.171265, 0.12378123,...,0.172364]。

这样，对于任意两个单词，我们可以用距离计算的方式来评价它们之间的联系。比如我们使用 cosin 距离计算“中国”和“北京”两个单词的距离，就大概率要比“中国”和“西瓜”的距离要近得多。

这样做有什么好处呢？首先，词与词之间的距离可以作为两个词之间相似性的度量。其次，向量空间隐含了很多的数学计算，比如经典的 V(国王)- V(皇后) = V(男人) - V(女人)，这让词语之间有了更多的语义上的关联。

除了维度，为了确定向量空间，我们还需要确定这个空间有多少个“点”，也就是词语的数量有多少。一般来说，我们是将语料库中出现超过一定阈值次数的单词保留，把这些留下来的单词的数量，作为空间点的量了。

我们具体看看实际的操作过程中是怎么做的。我们只需要建立一个 M*N 大小的矩阵，并随机初始化里面的每一个数值，其中 M 表示的是词语的数量，N 表示词语的维度。我们把这样矩阵叫做词向量矩阵。

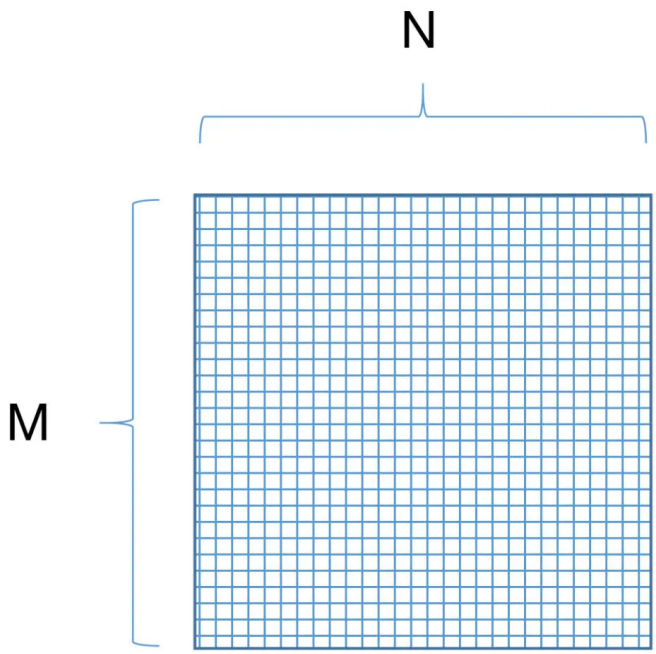

极客时间

既然是随机初始化的，那么就意味着这个向量空间不能作为我们的语言模型使用。下面我们就要想办法让这个矩阵学到内容。如下图：

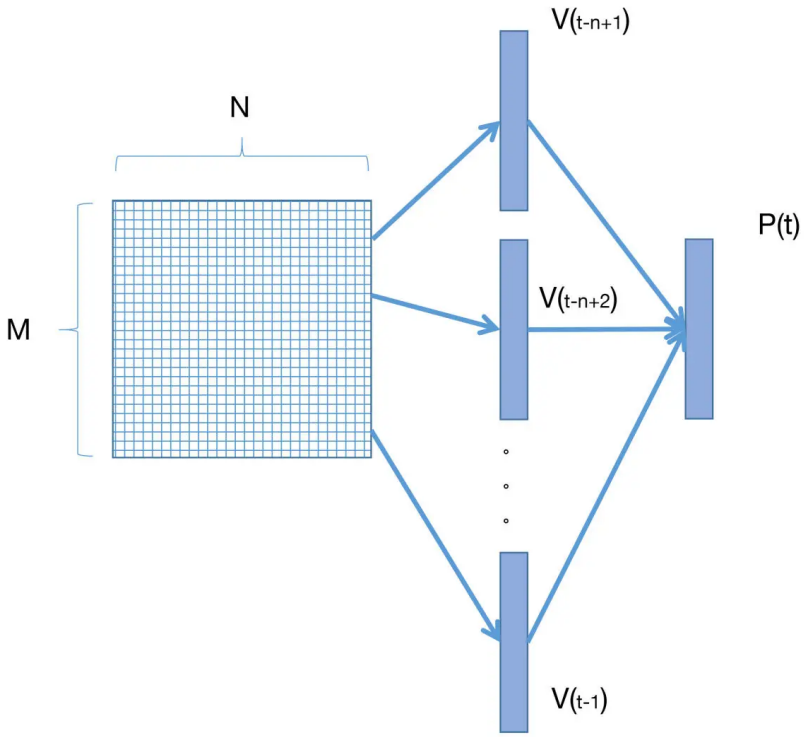

极客时间

刚才我们说过，神经网络语言模型也是通过 ngram 来进行语言建模的。假定我们的 ngram 长度为 n，那么我们就从词向量矩阵中找到对应的前 n-1 个词的向量，经过若干层神经网络（包括激活函数），将这 n-1 个词的向量映射到对应的条件概率分布空间中。最后，模型就可以通过参数更新的方式，学习词向量的映射关系参数，以及上下文单词出现的条件概率参数了。

简单来说就是，我们使用 n-1 个词，预测第 n 个词，并利用预测出来的词向量跟真实的词向量做损失函数并更新，就可以不断更新词向量矩阵，从而获得一个语言模型。这种类型的神经网络语言模型我们称之为**前馈网络语言模型**。

除了前馈网络语言模型，还有一种叫做基于 LSTM 的语言模型。下节课，我们将会通过 LSTM 完成情感分析任务的项目，进一步细化 LSTM 神经网络语言模型的训练过程，同时也会用到前面提到的词向量矩阵。

现在，我们回过头来比较一下统计语言模型和神经网络语言模型的区别。**统计语言模型的本质是基于词与词共现频次的统计，而神经网络语言模型则是给每个词分别赋予了向量空间的位置作为表征，从而计算它们在高维连续空间中的依赖关系**。相对来说，神经网络的表示以及非线性映射，更加适合对自然语言进行建模。

注意力机制

如果你足够细心就会发现，在前面介绍的神经网络语言模型中，我们似乎漏掉了一个点，那就是，对于一个由 n 个单词组成的句子来说，不同位置的单词，重要性是不一样的。因此，我们需要让模型“注意”到那些相对更加重要的单词，这种方式我们称之为注意力机制，也称作 Attention 机制。

既然是机制，它就不是一个算法，准确来说是一个构建网络的思路。关于注意力机制最经典的论文就是大名鼎鼎的《Attention Is All You Need》，如果你有兴趣的话，可以自行阅读这篇论文。

因为我们的专栏是以动手实践为主，重在实际应用各种机器学习的理论，所以不会对其内部的数学原理进行过多剖析，但是我们还是要知道它是怎么运作的。

我们从一个例子入手，比如“我今天中午跑到了肯德基吃了仨汉堡”。这句话中，你一定对“我”、“肯德基”、“仨”、“汉堡”这几个词比较在意，不过，你是不是没注意到“跑”字？

其实 Attention 机制要做的就是这件事：找到最重要的关键内容。它对网络中的输入（或者中间层）的不同位置，给予了不同的注意力或者权重，然后再通过学习，网络就可以逐渐知道哪些是重点，哪些是可以舍弃的内容了。

在前面的神经网络语言模型中，对于一个确定的单词，它的向量是固定的，但是现在不一样了，因为 Attention 机制，对于同一个单词，在不同语境下它的向量表达是不一样的。

下面这张图是 Attention 机制和 RNN 结合的例子。其中红色框中的是 RNN 的展开模式，我们可以看到，我 / 爱 / 极 / 客四个字的向量沿着绿色箭头的方向传递，每个字从 RNN 节点出来之后都会有一个隐藏状态 h，也就是输入节点上面的蓝色方框，在这个过程中每个状态的权重是一样的，不分大小。

而蓝色框就是 Attention 机制所加入的部分，其中的每个α就是每个状态 h 的权重，有了这个权重，就可以将所有的状态 h，加权汇总到 softmax 中，然后求和得到最终输出 C。这个 C 就可以为后续的 RNN 判断权重，提供更多的计算依据。

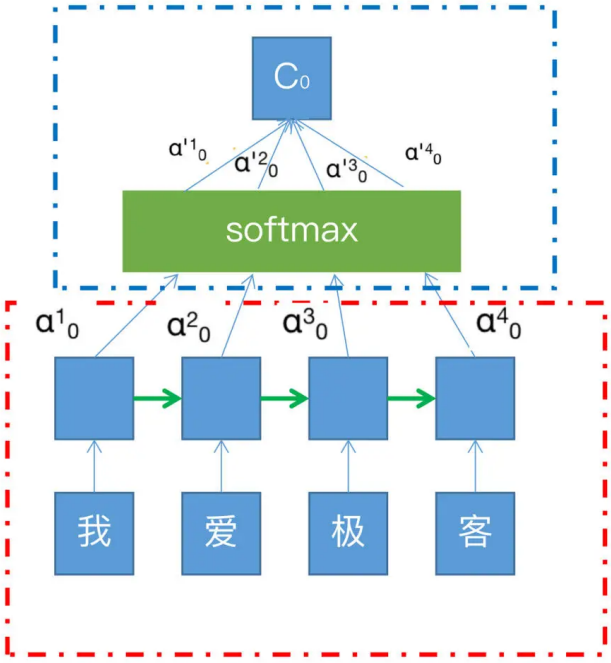

极客时间

你看，这个注意力机制的原理其实很简单，但是也很巧妙。只需要增加很少的参数，就可以让模型自己弄清楚谁重要谁次要。那么下面我们来看一下抽象化之后的 Attention，如下图，这张图想必你应该在很多 attention 的相关介绍中见过了。

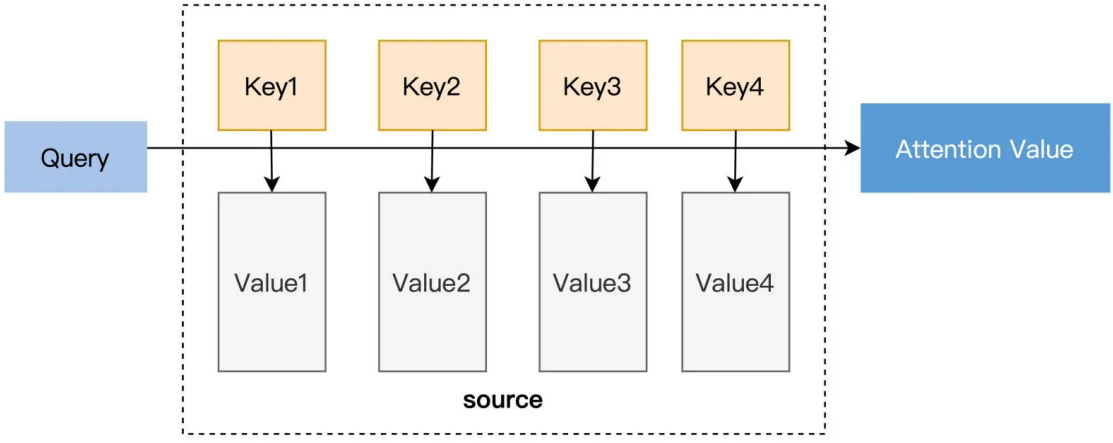

极客时间

在这里输入是 query(Q), key(K), value(V)，输出是 attention value。跟刚才 Attention 与 RNN 结合的图类比，query 就是上一个时间节点传递进来的状态 Zt-1，而这个 Zt-1 就是上一个时间节点输出的编码。key 就是各个隐藏状态 h，value 也是隐藏状态 h（h1, h2...hn）。模型通过 Q 和 K 的匹配公式计算出权重，再同 V 结合就可以得到输出，这就相当于计算得到了当前的输出和所有输入的匹配度，公式如下：

$$\text{Attention}(Q, K, V) = \text{softmax}(\text{sim}(Q, K))V$$

Attention 目前主要有两种，一种是 soft attention，一种是 hard attention。hard attention 关注的是当前词附近很小的一个区域，而 soft attention 则是关注了更大更广的范围，也更为常用。

作为应用者，你了解到 Attention 的基本原理就足够使用了，因为现在已经有了很多基于 Attention 的预训练模型可以直接使用。如果你想了解更深入，可以跟我在留言区和交流群中进一步讨论。

小结

恭喜你完成了今天的学习任务。

今天我们一起学习了语言模型的基本原理，了解了注意力机制如何给模型赋能，让模型更加“善解人意”，提高它抓取文本重点内容的能力。

通过语言模型，我们可以将语言文字变成可以计算的形式，让文字之间有了更为直接的关联。有了注意力机制，我们可以让模型了解到哪些是应该被更加关注的内容，从而提高语言模型的效果。如果你对注意力机制的数学原理感兴趣，并需要更深层次的专项学习，推荐你阅读《Attention Is All You Need》这篇论文。

至此我们通过两节课了解了 NLP 任务中的基础问题和重要内容，接下来的课程中，我们即将迎来动手操作环节。

首先是基于 LSTM 的情感分析项目，通过这个项目，你可以了解语言模型的构建方法，并可以实现一个由情感感知能力构成的模型。之后，我们还会使用目前火热的 Bert 模型来构建一个效果非常给力的文本分类模型，敬请期待。

每课一练

词向量的长度多少比较合适呢？越长越好吗？

欢迎你在留言区跟我交流互动，也推荐你把这节课分享给更多同事、朋友。

分享给需要的人，Ta订阅后你可得 20 元现金奖励

生成海报并分享

赞 1 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 21 | NLP基础（上）：详解自然语言处理原理与常用算法

下一篇 23 | 情感分析：如何使用LSTM进行情感分析？

更多学习推荐

精选留言

写留言

> 由作者筛选后的优质留言将会公开显示，欢迎踊跃留言。